

Os Agentes de Inteligência Artificial no Posto de Comando

Tenente-Coronel Michael Bowman, Exército dos EUA,
Gheorghe Tecuci, e
Mihai Boicu

A HABILIDADE de um comandante de tomar boas decisões sob condições adversas pode desequilibrar o resultado da batalha. Após setenta e duas horas operando, ele pode estar agüentando à base de café e sonecas.

No centro de operações táticas, o oficial de operações expõe três linhas de ação possíveis para uma nova missão. Ele recomenda a primeira linha de ação com convicção, explicando as suas vantagens. Algo relacionado à linha de ação incomoda o comandante. Talvez o cansaço, o estresse ou alguma outra distração estejam impedindo-o de lembrar lições aprendidas de outros campos de batalha ou eventos do adestramento que afetariam a sua decisão. O comandante toma uma decisão mas sente que talvez haja uma solução melhor — precisa de mais tempo, mais informação e uma mente mais clara e descansada.

As decisões tomadas pelos comandantes, oficiais de estado-maior e combatentes são fundamentadas na educação, no adestramento, na experiência ou na preferência pessoal. Uma vida de aprendizagem permite-lhes fixar metas, avaliar as condições, identificar e estudar alternativas e tomar decisões rápidas e complexas. A mente humana pode tomar decisões admiráveis sob condições extraordinárias — uma habilidade que falta na tecnologia. Porém, a mente é sujeita a efeitos adversos provenientes de fatores ambientais tais como a fadiga, o estresse e a fome. É bem documentado que as decisões tomadas sob estas condições são geralmente inferiores àquelas tomadas por líderes que se encontram descansados, bem alimentados e tranqüilos. O militar dos EUA se empenha em selecionar comandantes com base em sua habilidade

comprovada de tomar boas decisões sob condições adversas.

O cenário a seguir provê um bom exemplo de tomada de decisão sob condições adversas. Considere estas mesmas condições — com outra ferramenta de tomada de decisão para comandantes.

Um agente de inteligência artificial computadorizado é programado com lições aprendidas nas salas de aula e durante o adestramento. O *software* funciona nos mesmos computadores usados para escrever memorandos e criar diapositivos para apresentações. Ele acessa os dados nos sistemas de comando em combate e nas ferramentas de planejamento, incluindo poderosos sistemas de rede de computadores, notas escritas à mão e esboços.

O agente de inteligência artificial computadorizado ignora o tempo, a temperatura e a condição física e mental do comandante. Com base em toda a informação disponível, ele avalia as linhas de ação e prepara uma lista das vantagens, desvantagens e dos resultados em uma questão de segundos. O comandante então analisa a lista, ignora algumas linhas de ação enquanto considera outras até alcançar o elemento crítico da decisão. Ele decide com base no seu raciocínio, recomendações do seu estado-maior e alguns fatores-chave, que de outra forma não teria nem a energia nem o conhecimento para identificar.

As vantagens, desvantagens e resultados podem ter como base as considerações de planejamento aprendidas por um tenente durante um curso básico; descobertas por um capitão durante uma análise pós-ação; ou observadas nas escolas de altos estudos de outras forças armadas. Também podem ser com base as novas táticas inimigas observadas durante um combate no dia

anterior. O agente de inteligência artificial combina o que um computador faz melhor — separar e avaliar dados extensos, imune ao cansaço, estresse ou a fatores ambientais — com o que um ser humano faz melhor, como aprender por meio da experiência. Ele combina doutrina e táticas com lições aprendidas ao longo da história militar. Não substitui o comandante nem toma decisões por ele; proporciona informações concisas, relevantes e lógicas que o comandante pode considerar em seu processo de tomada de decisão. É desta maneira que podemos usar agentes de inteligência artificial no posto de comando do futuro.

O Laboratório dos Agentes de Aprendizagem

Sistemas automatizados de apoio às decisões, sistemas de perícia e agentes de inteligência artificial não são novidade, mas têm tido um papel limitado nos sistemas militares de comando e controle e apoio. Até mesmo com o crescimento rápido atual da computação e conectividade, a maioria dos produtos de *software* que alegam ser inteligentes não resolvem problemas complexos do mundo real. Pesquisadores do governo, da indústria e acadêmicos têm feito progresso recentemente, avançando os sistemas inteligentes do abstrato à realidade.

Uma abordagem recente para a criação e o uso dos agentes de inteligência artificial para resolver problemas militares complexos está em andamento na *George Mason University — GMU*, no *Learning Agents Laboratory — LALAB* (Laboratório de Agentes de Aprendizagem). A meta das pesquisas é desenvolver métodos e ferramentas que permitirão aos usuários, com um mínimo de conhecimento no uso do computador, construir, ensinar e manter com facilidade agentes de *software* inteligentes.¹ Esta abordagem permite aos usuários ensinarem o agente a executar tarefas da mesma maneira como ensinariam a um estudante ou aprendiz. Dá-se ao agente exemplos e explicações; seu comportamento é então supervisionado e corrigido.

Esta pesquisa foi feita como parte do projeto do *High-Performance Knowledge Base — HPKB* (Base de Dados de Grande Desempenho) do *Defense Advanced Research Projects Agency — DARPA* (A Agência de Projetos de Pesquisa Avançada do Departamento de Defesa) com apoio adicional do *US Air Force Office of Scientific Research* (Escritório de Pesquisas Científicas da Força Aérea dos EUA) e do *US Army Battle Command Battle Laboratory* (Laboratório Tático de Comando em Combate do Exército dos EUA). A meta do projeto *HPKB* era produzir a tecnologia para a rápida construção de grandes bases de dados que utilizassem tópicos de interesse de forma compreensiva, podendo ser usadas repetidas vezes por múltiplas aplicações com uma varie-

dade de estratégias para a resolução de problemas e com a capacidade de serem mantidas em ambientes de mudanças constantes.²

As organizações participantes da *HPKB* foram desafiadas a resolver problemas de bases de dados em um setor ou domínio em particular e então modificar seus sistemas rapidamente para resolver futuros problemas no mesmo setor. O exercício testou a afirmação que grandes bases de dados podem ser criadas rápida e eficientemente com tecnologia de ponta de inteligência artificial (*artificial intelligence – AI*). O trabalho continua

A maior barreira para a construção de sistemas inteligentes que resolvem problemas humanos é conhecida como “o gargalo de aquisição de dados” que ocorre quando se transferem dados do perito ao computador. A abordagem tradicional para a aquisição de dados e o desenvolvimento de agentes envolve a interação entre um experiente engenheiro de dados e um perito em informática.

como parte do Projeto da Formação Rápida de Dados (*Rapid Knowledge Formation Project*) do *DARPA* com o apoio da Força Aérea e do Exército. As avaliações e experimentos independentes do *DARPA* no Laboratório Tático de Comando em Combate do Exército dos EUA indicam que, com a abordagem certa, agentes de inteligência artificial podem resolver complexos problemas e serem construídos rapidamente e facilmente mantidos.

A Abordagem Tradicional e o Gargalo

Quer seja uma base de dados de física nuclear ou de uma lista de compras de supermercado, todos somos peritos em algo e tomamos decisões contínuas, às vezes instantaneamente. Aprendemos isso ao nascer; portanto a nossa astúcia na tomada de decisões tem base na experiência, no treinamento e nos hábitos de uma vida inteira. Reconhecer e demonstrar a habilidade de tomar decisões rápidas e sábias é fácil; entender e explicar como e porque tomamos as decisões é mais complicado. Geralmente, explicar e documentar decisões más não é menos complicado que explicar e documentar as boas. Quando se lhes pede uma explicação de como chegaram a uma decisão, a maioria das pessoas indicam um ou dois fragmentos de informação-chave. Normalmente acham difícil prover rapidamente uma lista de informações pertinentes ou estabelecer uma correlação entre as mesmas. Além disso, explicar satisfatoriamente como se

chegou a uma decisão específica muitas vezes deixa inexplicada uma solução generalizada.

Consideremos a compra de um pão de forma. Tome-mos um momento para determinar toda a informação necessária à tarefa:

Fundos para a compra do pão.

O lugar onde será efetuada a compra.

Transporte para chegar ao local.

Tipo de pão.

Método de pagamento.

E quanto à pergunta “saco de papel ou de plástico”? Quase nunca completamos a lista na primeira tentativa e tampouco o farão os peritos quando tentarem determinar todos os passos e fatores tomados na busca da solução de problemas complexos.

A maior barreira para a construção de sistemas inteligentes que resolvem problemas humanos é conhecida como “o gargalo de aquisição de dados” que ocorre quando se transferem dados do perito ao computador. A abordagem tradicional para a aquisição de dados e o desenvolvimento de agentes envolve a interação entre um experiente engenheiro de dados e um perito em informática. O engenheiro de dados deve aprender o que

A base de dados de um agente do Discípulo consiste de uma ontologia que define os termos do domínio aplicativo e um conjunto de regras expressas junto aos mesmos. A estratégia do Discípulo é substituir as tarefas difíceis de engenharia necessárias para a preparação de uma base de dados, com tarefas mais simples que um perito em assuntos possa executar.

o perito sabe e como este usa os dados para a resolução de problemas. O engenheiro de dados usa várias ferramentas e técnicas, mas depende principalmente de sua observação pessoal e entrevista.

Transferir dados indiretamente de um perito por meio de um engenheiro de dados e finalmente a um sistema computadorizado é particularmente difícil porque os peritos expressam seus dados de forma diferente de como se representam no sistema inteligente. Após providenciar uma base de dados, o perito deve verificar e fazer correções onde for necessário. Tal espécie de transferência indireta torna a aquisição de dados útil lenta, penosa e ineficiente.

Consideremos o desenvolvimento de um sistema perito hipotético. José é um engenheiro nuclear, trabalha há 30 anos em sua profissão e é o perito chefe de sua

instalação. Gerentes da instalação empregam uma firma de tecnologia da informação para desenvolver um agente de inteligência artificial para apoiar, ou até mesmo substituir, José. A firma de tecnologia da informação designa um engenheiro de dados para obter, documentar e formalizar os conhecimentos/dados de José e seu processo de resolução de problemas. O engenheiro de dados leva um ano para compreender e assimilar o que José sabe. Os dados assimilados concluem que, quando a luz vermelha do painel de controle de José começa a piscar, ele comprime o botão número cinco para impedir que a instalação exploda. O engenheiro de dados então leva outro ano para completar a base de dados que representa os conhecimentos/dados de José e para programar e purificar um sistema que usa esses dados para a resolução de problemas apropriados.

Após o segundo ano, o engenheiro de dados volta à instalação nuclear com o seu sistema já terminado e uma conta por serviços prestados pelos dois anos de trabalho. Para surpresa sua, é informado sobre a aposentadoria de José e que a instalação mudou o painel de controle de José com uma versão que já não inclui a luz vermelha que pisca ou o botão número cinco. O sistema que ele passou dois anos desenhando tornou-se obsoleto. No final, o sistema não foi usado, a instalação perdeu tempo e dinheiro e a reputação da firma de tecnologia de informação sofreu um golpe. Todos os envolvidos com este tipo de sistema sabem que deve existir um caminho melhor. As falhas reconhecidas nesta abordagem tradicional incluem:

Habilidade limitada em reciclar dados previamente desenvolvidos.

Aquisição lenta e ineficiente de dados.

Adaptação lenta de dados.

Escalonamento limitado no desenho/desenvolvimento de agentes.³

Adquirindo Dados para a Tomada de Decisões

Como pode um perito em assuntos, sem a experiência em engenharia de dados e apoio muito limitado de um engenheiro de dados, treinar um agente de inteligência artificial para resolver problemas? Para responder a esta pergunta desenvolvemos o módulo Discípulo contendo a teoria, a metodologia e as técnicas de aprendizagem, com o qual o perito em assuntos ensina o agente a executar várias tarefas que um perito ensinaria a um aprendiz. O agente aprende diretamente do perito, desenvolvendo e aprimorando a sua base de dados. Após vários

*ontologia: Na filosofia, a ontologia é o estudo metafísico do *ser em si*, as suas propriedades e os modos por que se manifesta. Em sistemas de bases de dados, uma ontologia é a parte do sistema que especifica quais coisas existem e o que é verdadeiro sobre elas. A ontologia da CYC é essencialmente o total de sua base de dados. Podem-se ouvir indivíduos referindo-se às suas “ontologias de dispositivos” ou à “ontologia temporal”. Estão se referindo àquelas partes da base de dados (as constantes e as confirmações) que têm a ver com dispositivos ou tempo.—Nota da Editoria Brasileira

anos, agentes de inteligência artificial cada vez mais avançados têm surgido da família do Discípulo.⁴

A base de dados de um agente do Discípulo consiste de uma ontologia (*) que define os termos do domínio aplicativo e um conjunto de regras expressas junto aos mesmos. A estratégia do Discípulo é substituir as tarefas difíceis de engenharia necessárias para a preparação de uma base de dados, com tarefas mais simples que um perito em assuntos possa executar.

Desenvolver uma base de dados requer a criação de uma ontologia que define o domínio aplicativo, estabelecendo regras ou métodos para a resolução de problemas, verificando e atualizando-as. Estas tarefas requerem a criação de sentenças e explicações formais. Na abordagem do Discípulo, estas tarefas são substituídas por tarefas mais simples que um perito em assuntos pode executar com apoio limitado por parte de um engenheiro de dados. Ao invés de criar uma ontologia, um perito precisa apenas atualizar e ampliar uma ontologia inicial importada das fontes de dados existentes. Em lugar de definir uma regra complexa para a resolução de problemas, o perito apenas define um exemplo específico de um episódio porque o Discípulo aprenderá uma regra desse exemplo. Em vez de alterar uma regra complexa de resolução de problemas, o perito considera exemplos específicos de episódios e o Discípulo fará a correspondente modificação à regra. Na maioria das vezes, o perito não precisará criar sentenças formais, mas apenas compreender as que são geradas pelo Discípulo. O perito não precisará proporcionar explicações formais, apenas dicas que permitam ao Discípulo gerar explicações plausíveis. O perito então escolhe as corretas.



Fotos: Departamento de Defesa

Soldados da 35ª Divisão de Infantaria trabalhando em um modelo de um centro de operações táticas no Forte Leavenworth, Kansas.

Discípulo

Um desafio para a segunda fase do *HPKB* era criticar as linhas de ação para operações de combate terrestre. Os grupos participantes usaram uma ontologia em comum desenvolvida pelas organizações de pesquisa que participaram do *HPKB*. Este era um desafio novo já que havíamos usado apenas ontologias desenvolvidas diretamente pelo Discípulo, particularmente bem adaptadas aos nossos meios de aprendizagem e aquisição de dados.

O Exército dos EUA providenciou as linhas de ação em um formato militar padronizado consistindo de uma descrição de múltiplos parágrafos e uma representação gráfica da linha de ação usando símbolos padronizados para unidades, atividades e relacionamentos geoespaciais. O agente do Discípulo identifica os pontos positivos e negativos das linhas de ação com respeito aos princípios de guerra e a doutrina de operações do Exército.⁵ Para

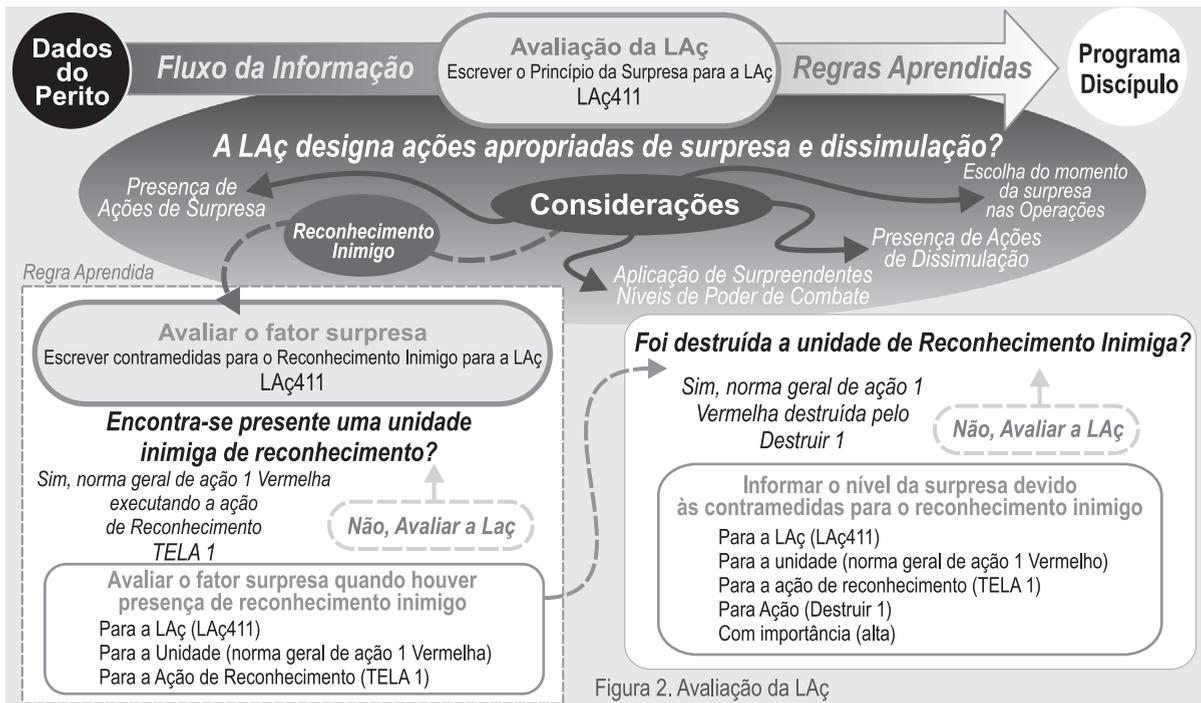


Figura 2. Avaliação da LAç

Instituto de Aplicações de Inteligência Artificial (*The Artificial Intelligence Applications Institute*) e a *Northwestern University* participaram do projeto *HPKB* e desenvolveram ferramentas que converteram o esboço e texto em arquivos de dados. Esta informação é coletivamente chamada uma ontologia. Uma ontologia do Discípulo inclui objetos, características e tarefas, todas representadas como quadros, de acordo com o modelo de dados *Open Knowledge Base Connectivity*.⁸ Um perito que treina um agente para o Discípulo não precisa trabalhar diretamente com a estrutura da ontologia ou da base de dados, mas, geralmente, compreender a estrutura e as informações contidas na base de dados o torna um treinador mais eficiente.

A figura 1 representa um fragmento do objeto da ontologia usado para modelar o campo da linha de ação. A parte de cima da figura representa o nível superior do objeto da ontologia que identifica os tipos de conceitos representados. A parte esquerda mostra um fragmento da hierarquia da moderna organização militar. Os níveis desta hierarquia são específicas unidades militares, correspondendo a uma determinada linha de ação sujeita ao critério do Discípulo. Cada conceito e instância do objeto da hierarquia é descrito por meio de valores e características específicas.

Nossa metodologia para explicar e documentar a tomada de decisão ou resolução do problema ao agente do Discípulo é a redução de tarefas. A redução de tarefas analisa um problema complexo e o reduz a uma série de tarefas menores até que o que sobrar seja um problema

que contém suficiente informação que permita chegar a uma conclusão.

Quer se ensine a um ser humano ou a uma máquina como resolver um problema, quem ensina deve saber como solucionar o problema antes de poder explicar o processo. Não há dúvida — analisar, documentar e verificar os detalhes da tomada de decisão não é um processo natural para os peritos a menos que também ensinem rotineiramente os candidatos a peritos. Ensinar um agente do Discípulo consiste em identificar a seqüência de passos (redução de tarefa) para o Discípulo e explicar quando e porque se avança de um passo a outro. As explicações poderiam ser uma série de considerações ou perguntas a fazer a cada passo e as respostas correspondentes que levariam ao seguinte (tarefa). As perguntas e respostas são expressas em um idioma natural e, quando combinadas com um diagrama (Fig. 2) que representa os passos de uma resolução de problema, servem de um roteiro para a interação entre o perito e o Discípulo durante uma sessão de treinamento de um agente.

O Discípulo aprende uma regra geral, plausível, da versão-espaco (*) da tarefa-redução à medida que o perito indica cada passo na redução da tarefa (representado por uma tarefa, uma pergunta, a resposta e uma subtarefa). Esta complexa estrutura “se-então” indica as condições sob as quais a tarefa da parte “se” da regra

(*) A versão-espaco é uma representação hierárquica de conhecimento ou dados que permite localizar toda a informação útil proporcionada por uma seqüência de exemplos de aprendizagem sem lembrar de nenhum dos exemplos.— Nota da Editoria Brasileira

pode ser reduzida à tarefa (ou tarefas) da parte “então” da mesma. Porém, ao invés de uma única condição aplicável, a regra especifica um espaço de hipótese plausível para a sua condição. Uma condição plausível com limite superior e outra com limite inferior representam essa versão-espaço plausível. Durante maiores aprendizados do perito, estes dois limites irão convergir. Além das condições necessárias à aplicação da regra, esta poderá ter várias condições “com exceção de” (que especificam instâncias que são exceções negativas à regra) e condições “para” (que especificam exceções positivas). Muito do poder do método do Discípulo é proveniente da regra da versão-espaço plausível.

O perito nunca tem que ver nem lidar com estas regras de resolução de problemas, apenas com exemplos específicos. Na abordagem tradicional, peritos devem explicar este raciocínio aos engenheiros de dados que codificam manualmente estes dados den-

ção. Se o perito encontra uma solução incorreta, ele a rejeita e ajuda o Discípulo a compreender porque a solução era equivocada. Isto ajuda o Discípulo a isolar a regra que produziu a solução errada para que não gere a mesma solução no futuro. Desta maneira, o Discípulo continuamente aprende do perito enquanto amplia e aprimora sua base de dados.

Um dos pontos mais fortes da abordagem do Discípulo é que o perito não tem que conduzir um treinamento de agente perfeito ou compreensivo. As falhas no treinamento aparecem imediatamente quando o Discípulo resolve problemas por si próprio, e o perito apenas examina as soluções do Discípulo e explica onde foi feito o erro. De extrema importância é o fato que o Discípulo aprende por meio de exemplo. Treinar um agente a criticar linhas de ação requer exemplos das mesmas — ambos uma vantagem e uma desvantagem. A desvantagem mais óbvia é a necessidade de exemplos. A vantagem é que a maioria dos peritos examinam um exemplo naturalmente e oferecem explicações com base no mesmo.

Resultados Experimentais

A metodologia do Discípulo e os agentes desenvolvidos para o Discípulo foram testados com outros sistemas como parte do programa anual *HPKB* de avaliações do *DARPA*. Os resultados do experimento mostraram que os agentes com base no Discípulo, preparados por equipes de peritos e engenheiros de dados, foram muito eficazes na resolução de problemas complexos e produziram altos níveis de aquisição de dados, tendo um desempenho superior a outros sistemas desenvolvidos pelo *HPKB* referentes aos mesmos desafios problemáticos.⁹

Após julho de 1999, concentramos nossos esforços em desenhar e conduzir um experimento de aquisição de dados com uma semana de duração no Laboratório Tático de Comando em Combate do Exército dos EUA no Forte Leavenworth, Kansas. O experimento demonstrou que peritos militares podem ensinar diretamente os agentes do Discípulo como avaliar uma linha de ação, usando vários princípios de guerra e a doutrina operacional do Exército. Nossos peritos em assuntos eram quatro oficiais das armas combatentes da Ativa do Exército dos EUA com 16 a 22 anos de serviço militar e com experiência anterior em engenharia de dados. O experimento foi feito em três fases — uma fase de treinamento para peritos (dias 1-3), uma fase de experimento (dia 4), e uma discussão conjunta sobre o experimento (dia 5). A fase de treinamento dos peritos apresentou o propósito do experimento, a história e atual estado da Inteligência do Exército, estrutura e conteúdo da ontologia da linha de ação e exercícios práticos usando o Discípulo.

Nossa visão a longo prazo é desenvolver uma capacidade que permita ao típico usuário do computador desenvolver e manter agentes de inteligência artificial e bases de dados tão facilmente quanto usa seu computador para o processamento de texto ou correio eletrônico. Esta pesquisa pretende que os agentes de inteligência sejam ensinados por um perito ao invés de serem programados por um engenheiro de dados.

tre as regras de resolução de problemas e as aperfeiçoam. Com o Discípulo, o perito ensina diretamente o agente que, por sua vez, aprende e refina as regras.

Treinar um agente para o Discípulo é um processo repetitivo de fornecer exemplos e explicações ao agente, permitindo-o tentar resolver problemas e explicar porque suas soluções são corretas ou erradas. Usando a interface de usuário gráfica, o perito identifica o problema a ser resolvido. O Discípulo tentará resolver o problema por meio da aplicação das regras de versão-espaço plausíveis que reduzem o problema a problemas menores. O perito então examina estas soluções e tem três opções. Se o perito não encontra a solução correta, ele proporcionará uma e ajudará o agente a compreendê-la e o Discípulo assim aprende mais uma regra de versão-espaço plausível. Se o perito encontra uma solução viável entre as propostas, o Discípulo generaliza a regra que produziu essa solu-

Durante a fase experimental, os oficiais treinaram agentes do Discípulo a criticarem linhas de ação com referência aos princípios da ofensiva e segurança, começando com uma base de dados contendo a ontologia completa de objetos e características — mas sem regras. Suas sessões de treinamento com agentes durou aproximadamente três horas e não receberam nenhuma assistência significativa dos engenheiros de dados. Todos os peritos ampliaram a base de dados da linha de ação do Discípulo com 28 tarefas e 26 regras, seguindo o modelo para avaliar linhas de ação que receberam no início do experimento. No final do experimento, a pesquisa julgou muito positiva a utilidade e o aproveitamento do Discípulo.

O experimento foi a maior realização de nossa pesquisa em 1999. Foi a primeira vez na qual um perito, sem prévia experiência em engenharia de dados, treinou um agente de inteligência artificial para resolver um problema complexo e ampliar uma significativa base de dados. Outrossim, isto ocorreu rapidamente e sem o apoio de um engenheiro de dados.

Como parte do programa *HPKB* do *DARPA*, o método do Discípulo com relação ao desenvolvimento de um agente de inteligência artificial foi conduzido e concluiu que o mesmo:

Aumenta significativamente a velocidade no processo de desenvolvimento e atualização de um agente de inteligência artificial e a expectativa de uma base de dados de alto desempenho.

Permite aos peritos aprenderem rapidamente o conhecimento relativo à resolução de problemas com as-

sistência limitada por parte de engenheiros de dados.

Proporciona conhecimento suficiente na resolução de problemas para que o agente desenvolva soluções de alto nível.

Nossa visão a longo prazo é desenvolver uma capacidade que permita ao típico usuário do computador desenvolver e manter agentes de inteligência artificial e bases de dados tão facilmente quanto usa seu computador para o processamento de texto ou correio eletrônico. Esta pesquisa pretende que os agentes de inteligência sejam ensinados por um perito ao invés de serem programados por um engenheiro de dados. **MR**

REFERÊNCIAS

1. Gheorghe Tecuci, *Building Intelligent Agents: An Apprenticeship Multistrategy Learning Theory, Methodology, Tool and Case Studies* (San Diego, CA: Academic Press, 1998).
2. Paul Cohen et al., "The DARPA High-Performance Knowledge Bases Project," *AI Magazine* (Winter 1998), pp 25-49.
3. Tecuci.
4. *Ibid.*; *Technical Aspects of Disciple* disponível no <www.lalab.gmu.edu>.
5. *Ibid.*
6. *US Army Field Manual 100-5, Operations* (Washington, DC: US Government Printing Office, 1993).
7. Douglas B. Lenat, "CYC: A Large-Scale Investment in Knowledge Infrastructure," *Communications of the ACM* (November 1995), pp 33-38.
8. Vinay Chaudhri et al., "OKBC: A Programmatic Foundation for Knowledge Base Interoperability," in *AAAI-98 Proceedings* (Menlo Park, CA: American Association for Artificial Intelligence [AAAI] Press, 1998), pp 600-607.
9. Michael Bowman, Gheorghe Tecuci and Mihai Boicu, "A Methodology for Modeling and Representing Expert Knowledge that Supports Teaching-Based Intelligent Agent Development," in *Proceedings of the Seventeenth National Conference on Artificial Intelligence and the Twelfth Conference on Innovative Application of Artificial Intelligence* (Menlo Park, CA: AAAI Press, July 2000).

O Tenente-Coronel Michael Bowman, é estudante na Escola de Guerra do Exército dos EUA, Carlisle Barracks, na Pennsylvania. É bacharel pelo Ouachita Baptist University, tem um mestrado pelo U.S. Naval Postgraduate School e é candidato a Ph.D pela George Mason University. Teve várias posições de comando e estado-maior, incluindo gerente de produto, Sistemas de Apoio de Comunicações e Inteligência (Communications and Intelligence Support Systems), Forte Belvoir, Virgínia; chefe, Automação e Programas (Automation and Software), Subchefe de Estado-Maior para Pesquisa, Desenvolvimento e Aquisição, QG do Comando de Material do Exército dos EUA (U.S. Army Materiel Command), em Alexandria, na Virgínia; e oficial de integração de sistemas conjuntos, Agência de Inteligência de Defesa (Defense Intelligence Agency), em Washington, D.C.

Gheorghe Tecuci é professor de ciência da computação e diretor no Laboratório de Agentes de Aprendizagem (Learning Agents Laboratory), Departamento da Ciência da Computação (Department of Computer Science), na George Mason University, em Fairfax, Virgínia. É mestre pela Polytechnic University of Bucharest, na Romênia. É Ph.D pela University of Paris-South, na França, e pelo Polytechnic University of Bucharest. Serviu em várias posições de pesquisa e assessoramento, incluindo professor associado em ciência da computação, Escola de Engenharia e Tecnologia da Informação (School of Information Technology and Engineering) da George Mason University e pesquisador senior no Instituto de Pesquisa para Informática (Research Institute for Informatics), em Bucareste, Romênia. Publicou mais de 100 documentos científicos e cinco livros sobre inteligência artificial.

Mihai Boicu é candidato a Ph.D pela Escola de Engenharia e Tecnologia da Informação (School of Information Technology and Engineering), na George Mason University. É mestre pela University of Bucharest, na Romênia. Serviu em várias posições de pesquisa e assessoramento, incluindo assistente em pesquisa graduada na Escola de Engenharia e Tecnologia da Informação (School of Information Technology and Engineering) da George Mason University, e professor vitalício do Departamento de Ciência da Computação (Computer Science Department), do Instituto de Pesquisa para Informática (Research Institute for Informatics), em Bucareste, Romênia. Publicou mais de 15 documentos sobre a inteligência artificial.